




별첨 사본은 아래 출원의 원본과 동일함을 증명함.

This is to certify that the following application annexed hereto
is a true copy from the records of the Korean Intellectual
Property Office.

출원번호 : 10-2002-0041406
Application Number

출원년월일 : 2002년 07월 15일
Date of Application JUL 15, 2002


출원인 : 삼성전자주식회사
Applicant(s) SAMSUNG ELECTRONICS CO., LTD.



2003 년 07 월 10 일

특 허 청

COMMISSIONER



【서지사항】

【서류명】	특허출원서
【권리구분】	특허
【수신처】	특허청장
【참조번호】	0001
【제출일자】	2002.07.15
【발명의 명칭】	LDA 프로젝션에 GDA를 적용한 얼굴 디스크립션 산출 방법
【발명의 영문명칭】	FACE DESCRIPTION YIELDING METHOD APPLIED GDA TO LDA PROJECTIONS
【출원인】	
【명칭】	삼성전자 주식회사
【출원인코드】	1-1998-104271-3
【대리인】	
【성명】	김동진
【대리인코드】	9-1999-000041-4
【포괄위임등록번호】	2002-007585-8
【발명자】	
【성명의 국문표기】	김현우
【성명의 영문표기】	KIM,Hyun Woo
【주민등록번호】	720109-1140110
【우편번호】	449-900
【주소】	경기도 용인시 기흥읍 삼성종합기술원 기숙사 A동 213호
【국적】	KR
【발명자】	
【성명의 국문표기】	기석철
【성명의 영문표기】	KEE,Seok Cheol
【주민등록번호】	640428-1019213
【우편번호】	449-900
【주소】	경기도 용인시 기흥읍 삼성아파트 104동 701호
【국적】	KR
【발명자】	
【성명의 국문표기】	김태균
【성명의 영문표기】	KIM,Tae Kyun
【주민등록번호】	760504-1690817

【우편번호】 449-900
【주소】 경기도 용인시 기흥읍 구갈리 365-3
【국적】 KR
【발명자】
【성명의 국문표기】 황원준
【성명의 영문표기】 HWANG, Won Jun
【주민등록번호】 760511-1768127
【우편번호】 156-091
【주소】 서울특별시 동작구 사당1동 1005-2
【국적】 KR
【취지】 특허법 제42조의 규정에 의하여 위와 같이 출원합니다. 대
리인 김동
진 (인)
【수수료】
【기본출원료】 12 면 39,000 원
【가산출원료】 0 면 0 원
【우선권주장료】 0 건 0 원
【심사청구료】 0 항 0 원
【합계】 39,000 원
【첨부서류】 1. 요약서·명세서(도면)_1통

【요약서】**【요약】**

본 발명은 컴포넌트 기반 선형 판별 분석(Component-based Linear Discriminant Analysis : LDA라 함)의 결과에 일반 판별 분석(General Discriminant Analysis : GDA라 함)을 적용하여 더욱 정확한 얼굴 인식율을 달성할 수 있도록 하는 LDA 프로젝트에 GDA를 적용한 얼굴 디스크립션 산출 방법에 관한 것으로, 얼굴 요소별로 추출된 LDA 프로젝션을 하나의 단일 벡터로 머징하고 GDA를 사용하여 최종 얼굴 디스크립션을 산출하는 것을 특징으로 한다.

【대표도】

도 1

【색인어】

판별 분석, LDA, GDA, 얼굴 요소, 디스크립션

【명세서】

【발명의 명칭】

LDA 프로젝션에 GDA를 적용한 얼굴 디스크립션 산출 방법 {FACE DESCRIPTION
YIELDING METHOD APPLIED GDA TO LDA PROJECTIONS}

【도면의 간단한 설명】

도 1은 본 발명에 따라 LDA 컴포넌트에 GDA를 적용하는 전체적인 절차를 설명하는
도면.

【발명의 상세한 설명】

【발명의 목적】

【발명이 속하는 기술분야 및 그 분야의 종래기술】

<2> 본 발명은 컴포넌트 기반 선형 판별 분석(Component-based Linear Discriminant
Analysis : LDA라 함)의 결과에 일반 판별 분석(General Discriminant Analysis : GDA라
함)을 적용하여 더욱 정확한 얼굴 인식율을 달성할 수 있도록 하는 LDA 프로젝션에 GDA
를 적용한 얼굴 디스크립션 산출 방법에 관한 것이다.

<3> GDA는 기존의 기술이지만 이를 얼굴 요소별로 추출한 LDA 결과값에 적용하는 경우
더 정확한 얼굴인식률을 달성할 수 있음을 알았다.

【발명이 이루고자 하는 기술적 과제】

<4> 본 발명의 목적은 얼굴 요소별로 추출한 LDA 결과값에 GDA 적용하여 더욱 정확한
얼굴 인식율을 달성할 수 있도록 하는 것이다.

- <5> 상술한 목적을 달성하기 위한 본 발명은 얼굴 요소별로 추출된 LDA 프로젝션을 하나의 단일 벡터로 머징하고 GDA를 사용하여 최종 얼굴 디스크립션을 산출하는 것을 특징으로 한다.

【발명의 구성 및 작용】

- <6> 이하, 첨부된 도면을 참조하여 본 발명을 상세히 설명하기로 한다.
- <7> 도 1은 본 발명에 따라 LDA 컴포넌트에 GDA를 적용하는 전체적인 절차를 설명하는 도면이다.
- <8> GDA 는 비선형 특징 추출을 위해 설계된 방법이다. GDA 목적은 클래스 사이의 분산과 선형 경우에서 변형된 데이터의 전체 분산 사이의 비율을 최대화하는 비선형 분산을 탐색하는 것이다. 분산 사이의 최대 비율은 LDA 와 유사한 고유치 분석을 통해 얻어진다
- <9> 비선형 확장은 오리지널 공간(Y)으로부터의 데이터를 함수($\phi : Y \rightarrow Z$)에 의해 새로운 고차원 특징 공간(Z)에 매핑함으로써 실행된다. 새로운 공간(Z)의 고차원성 문제는 커널 함수($k: Y \times Y \rightarrow R$)를 사용하여 방지된다. 커널 함수의 값, $k(y_i, y_j)$ 은 비선형적으로 매핑된 벡터 $\phi(y_i)$ 와 $\phi(y_j)$, 예를들면 데이터가 확실한 매핑없이 고차원 공간으로 효율적으로 평가될 수 있는 $k(y_i, y_j) = \phi(y_i)^T \phi(y_j)$ 의 내적과 같다.
- <10> $y_{k,i}$ 가 k 번째 클래스의 i 번째 트레이닝 패턴이고, M 이 클래스의 수이고, N_i 가 i 번째 클래스에서의 패턴 수를 표시하며,
$$N = \sum_{k=1}^M N_k$$
 가 모든 패턴의 수를 표시한다고 하자. 데이터가 집중된다고 가정하면, 비선형적으로 매핑된 데이터의 전체 스캐터 매트릭스(scatter matrix)는

<11>

$$S_T = \frac{1}{N} \sum_{k=1}^M \sum_{i=1}^{N_k} \Phi(y_{k,i}) \Phi(y_{k,i})^T \text{ 이다.}$$

<12>

비선형적으로 매핑된 클래스간 스캐터 매트릭스는 $S_B = \frac{1}{N} \sum_{k=1}^M N_k \Phi(\mu_k) \Phi(\mu_k)^T$ 로서 정의되며, 여기서

<13>

$$\Phi(\mu_k) = \frac{1}{N_k} \sum_{i=1}^{N_k} \Phi(y_{k,i}) \text{ 이다.}$$

<14>

GDA의 목적은 다음과 같은 비율을 최대화하는 프로젝션 벡터 $w \in Z$ 를 탐색하는 것이다.

<15>

$$\lambda = \frac{w^T S_B w}{w^T S_T w} \quad (1).$$

<16>

식(1)를 최대화하는 벡터 $w \in Z$ 가 일반화된 고유치 문제의 해결책이라고 잘 알려져 있다.

<17>

$$\lambda S_T w = S_B w, \quad (2)$$

<18>

여기서 λ 는 고유벡터 w 에 대응하는 고유치이다. 소정의 집중된 패턴 y 의 새로운 표현은 가장 큰 고유치를 갖는 d 고유벡터에 대한 그것의 프로젝션 yTw 으로서 계산된다

<19>

커널 함수를 사용하기 위해 모든 계산은 내적 항에서 수행되어야 한다. 지금까지, 프로젝션 벡터 w 는 예를들면 다음과 같은 트레이닝 패턴의 선형 조합으로 표현된다.

<20>

$$w = \sum_{k=1}^M \sum_{i=1}^{N_k} \alpha_{k,i} \Phi(y_{k,i}), \quad (3)$$

<21> 여기서, $a_{k,i}$ 는 일부 실제 가중치이다. 식(3)을 사용하여 비율 (1)은 다음과 같이 표현될 수 있다.

<22>

$$\lambda = \frac{\alpha^T KWK\alpha}{\alpha^T KK\alpha}, \quad (4)$$

<23> 여기서, 벡터 $a = (a_k)$, $k=1, \dots, M$ 및 $a_k = (a_{k,i})$, $i=1, \dots, N_k$ 이다. 커널 매트릭스 $K(N \times N)$ 는 예를 들어 다음과 같이 비선형적으로 매핑된 데이터의 내적으로 구성된 다.

<24>

$$K = (K_{k,l})_{k=1, \dots, M, l=1, \dots, M} \quad (5)$$

<25> 여기서, $K_{k,l} = (k(y_{k,i}, y_{l,j}))_{i=1, \dots, N_k, j=1, \dots, N_l}$.

<26> 매트릭스 $W(N \times N)$ 는 다음과 같은 블록 대각선 매트릭스이다.

<27>

$$W = (W_k)_{k=1, \dots, M} \quad (6)$$

<28> 여기서, 위 대각선에서 k 번째 매트릭스는 $\frac{1}{N_k}$ 과 동일한 모든 엘리먼트를 가진다.

<29> 고유치 문제(4)의 해는 프로젝션 벡터 $w \in Z$ 를 정의하는 계수 벡터 a 를 산출한다. 테스트 벡터 y 의 프로젝션은 다음과 같이 계산된다.

<30>

$$w^T \Phi(y) = \sum_{k=1}^M \sum_{i=1}^{N_k} \alpha_{k,i} k(y_{k,i}, y). \quad (7)$$

<31> 이미 언급된 바와 같이, 트레이닝 벡터는 특징 공간 Z 에 집중될 것으로 가정된다. 집중 벡터 $\phi(y)'$ 는 다음과 같이 계산된다.

<32>

$$\Phi(y)' = \Phi(y) - \frac{1}{N} \sum_{k=1}^M \sum_{i=1}^{N_k} \Phi(y_{k,i}), \quad (8)$$

<33>

식(8)은 데이터가 내적의 항에서만 나타나기 때문에 집중된 커널 매트릭스 K' (K 대신에)를 사용하여 암시적으로 수행될 수 있다. 집중된 커널 매트릭스 K' 는 다음과 같이 계산된다.

<34>

$$K' = K - \frac{1}{N} IK - \frac{1}{N} KI - \frac{1}{N^2} IKI,$$

<35>

여기서, 매트릭스 I ($N \times N$) 는 I 와 동일한 모든 엘리먼트를 가진다. 유사하게 테스트 벡터 y 는 식(7)에 의한 프로젝팅 이전에 식(8)에 의해 형성되어야 한다. 테스트 벡터 y 에 대한 식(8)과 식 (7)의 적용은 프로젝션을 위해 다음 항을 사용하는 것과 동등하다.

<36>

$$w^T \Phi(y)' = \sum_{k=1}^M \sum_{i=1}^{N_k} \beta_{k,i} k(y_{k,i}, y) + b. \quad (10)$$

<37>

집중된 계수 $\beta_{k,i}$ 는 다음 식(11)과 식(12)로 계산된다.

<38>

$$\beta_{k,i} = \alpha_{k,i} - \frac{1}{N} J \alpha, \quad (11)$$

$$b = -\frac{1}{N} JKJ \alpha + \frac{1}{N^2} J \alpha JKJ, \quad (12)$$

<39>

여기서, 열 벡터 J ($N \times 1$) 는 I 와 동일한 모든 항을 가지고 b 는 편의(bias)이다.

<40>

전체 GDA 절차는 다음 단계들로 요약된다:

<41>

1. 집중 커널 매트릭스 K' (9) (5) 와 매트릭스 $\#$ (6)를 계산한다.

<42>

2. 일반화된 고유치 문제(4)를 해결함으로써 계수 벡터 a 를 계산한다.

<43> 3. 계수 벡터 β (11) 및 편의(biases) b (12)를 계산한다.

<44> 4. 식(10)을 사용하여 테스트 벡터 y 의 프로젝션을 계산한다.

<45> 컴포넌트 기반 LDA 얼굴 디스크립터(Component-based LDA Face Descriptor : CLFD

)는 처리된 얼굴 x_i 의 특정 영역의 LDA 프로젝션이 되는 특징 벡터 세트

$y_i^1, y_i^2, \dots, y_i^L$ 에 의해 i 번째 트레이닝 벡터 x_i 를 기술한다. 우리는 모든 특징 벡터
를 단일 벡터 $y_i = [y_i^1, y_i^2, \dots, y_i^L]$ 로 머징하고 GDA 를 사용하여 관련 특징 벡터 Z_i
를 추출하는 것을 제안한다. 전체적인 절차는 다음과 같이 요약된다:

<46> 1. 각 트레이닝 얼굴 x_i 에 대한 LDA 컴포넌트 $y_i^1, y_i^2, \dots, y_i^L$ 를 계산한다.

<47> 2. 모든 컴포넌트를 단일 벡터 $y_i = [y_i^1, y_i^2, \dots, y_i^L]$ 로 머징함으로써 각각의 얼굴
을 기술한다.

<48> 3. GDA 절차를 새로운 표현 z_i 을 산출하는 벡터 y_i 에 적용한다.

<49> 전체적인 절차에 대한 설명은 도 1를 참조하라.

<50> 실험

<51> 제안된 시도는 얼굴 수정 실험에서 테스트되었다. MPEG 와 ALTKOM 얼굴 데이터베이스가 실험에 사용되었다. 5번의 실험이 표 1에 기술된 트레이닝 및 테스트 세트에 대한 파티셔닝으로 실행되었다.

<52> [표 1]

<53>

	트레이닝 세트	테스트 세트
<p>실험 1</p> <p>(MPEG)</p>	<p>200 이미지</p> <p>40인*5이미지/1인</p> <p>mpeg_0066_01- mpeg_0085_05</p> <p>mpeg_0181_01- mpeg_0200_05</p>	<p>2975 이미지:</p> <p>595인*5이미지/1인</p> <p>(모든 이미지 파일 - 버전 1 디스크립터에 의해 사용된 트레이닝 세트)</p>

<54>

<p>실험 2</p> <p>(MPEG)</p>	<p>800 이미지:</p> <p>160인*5이미지/1인</p> <p>(사람 ID 필드가 xxx2 또는 xxx4 인 이미지 파일 + 버전 1 디스크립터에 의해 사용된 트레이닝 세트)</p>	<p>2375 이미지:</p> <p>475인*5이미지/1인</p> <p>(모든 이미지 파일 - 사람 ID 필드가 xxx2 또는 xxx4 인 이미지 파일 - 버전 1 디스크립터에 의해 사용된 트레이닝 세트)</p>
<p>실험 3</p> <p>(MPEG)</p>	<p>1685 이미지:</p> <p>337 인*5이미지/1인</p> <p>(사람 ID field가 우수인 이미지 파일 + 버전 1 디스크립터에 의해 사용된 트레이닝 세트)</p>	<p>1490이미지:</p> <p>298인*5이미지/1인</p> <p>(사람 ID field가 기수인 이미지 파일 - 버전1 디스크립터에 의해 사용된 트레이닝 세트)</p>
<p>실험 4</p> <p>(MPEG+ALTKOM)</p> <p>[트레이닝:테스트=1:4]</p>	<p>1035 이미지:</p> <p>(사람 ID 필드가 xxx1 또는 xxx6인 이미지 파일 + 버전1 디스크립터에 의해 사용된 트레이닝 세트)</p>	<p>3340 이미지:</p> <p>(모든 이미지 파일 - 이미지 파일 - 버전1 디스크립터에 의해 사용된 트레이닝 세트)</p>
<p>실험 5</p> <p>(MPEG+ ALTKOM)</p> <p>[트레이닝:테스트=1 1]</p>	<p>2285이미지:</p> <p>(사람 ID 필드가 우수인 이미지 파일 + 버전1 디스크립터에 의해 사용된 트레이닝 세트)</p>	<p>2090 이미지:</p> <p>(사람 ID 필드가 기수인 이미지 파일 - 버전1 디스크립터에 의해 사용된 트레이닝 세트)</p>

<55> 특별한 경우에, 각각의 얼굴 x_i 는 5 LDA 컴포넌트 벡터 $y_i^1, y_i^2, \dots, y_i^5$ 및 전체 얼굴 y_i^6 의 1 LDA 프로젝션으로 기술된다. 프로젝션 y_i^6 은 전체론적 프로젝션으로서 표기된다. 머징된 벡터 y 로부터, 각 컴포넌트 $y_i^1, y_i^2, \dots, y_i^5$ 중 25 개 가장 중요한 좌표 및 전체론적 프로젝션 y_i^6 중 50 개의 가장 중요한 좌표가 사용된다. 결과적으로, $5 \times 25 + 50 = 175$ -차원 벡터 $y_i = [y_i^1, y_i^2, \dots, y_i^6]$ 가 얻어진다.

<56> 4개의 서로다른 얼굴 상제는 다음과 같이 비교되었다:

<57> 1. 전체론적 디스크립터: 얼굴은 전체적인 LDA 프로젝션 y_i^6 중 50개의 가장 중요한 좌표에 의해 기술된다.

<58> 2. 머징된 디스크립터: 얼굴은 175-차원 머징된 벡터 $y_i = [y_i^1, y_i^2, \dots, y_i^6]$ 에 의해 기술된다.

<59> 3. 머징된 - LDA 디스크립터: 얼굴은 머징된 벡터 $y_i = [y_i^1, y_i^2, \dots, y_i^6]$ 의 LDA 프로젝션중 50개의 가장 중요한 좌표에 의해 기술된다.

<60> 4. 머징된 - GDA 디스크립터: 얼굴은 머징된 벡터 $y_i = [y_i^1, y_i^2, \dots, y_i^6]$ 의 GDA 프로젝션중 50개의 가장 중요한 좌표에 의해 기술된다.

<61> GDA 절차는 선형 또는 비선형 특징 추출을 정의하는 광범한 커널 함수의 사용을 가능케 한다. RBF(Radial Basis Function) 커널 $k(y_i, y_j) = e^{-0.5 \|y_i - y_j\|^2 / \sigma}$ 이 사용되었고, 커널 폭은 최상의 ANMRR비를 산출하도록 실험적으로 결정되어진다.

<62> 실험동안 (i) ANMRR(Average Normalized Modified Recognition Rate) 와 (ii) 테스트 세트에 대한 FIR(False Identification Rate)를 측정했다.

<63> 결과는 표 2 에 나열되어 있다. 실험 1 을 제외하고 다른 실험에서는 머징된 GDA 디스크립터가 성능이 더 나음을 알 수 있다. 실험 1 에서의 머징된 GDA 의 빈약한 성능은 대응하는 트레이닝 세트가 단지 300 얼굴로 구성되기 때문에 오버-트레이닝 효과에 기인한다.

<64> [표 2]

<65>

	실험 1		실험 2		실험 3		실험 4		실험 5	
	ANMRR	FIR	ANMRR	FIR	ANMRR	FIR	ANMRR	FIR	ANMRR	FIR
전체론적	0.1701	0.0666	0.1448	0.0573	0.1267	0.0477	0.2911	0.1060	0.1950	0.0641
머징된	0.1391	0.0491	0.1190	0.0421	0.1061	0.0336	0.2293	0.0641	0.1543	0.0373
머징된-LDA	0.3565	0.1983	0.1257	0.0467	0.0898	0.0222	0.2457	0.0731	0.1466	0.0368
머징된-GDA	0.2547	0.1318	0.1031	0.0358	0.0677	0.0168	0.2129	0.0545	0.1108	0.0239

【발명의 효과】

<66> 기존의 기술인 GDA를 얼굴요소별로 추출한 LDA 결과값에 적용하여 만들어진 본 시스템의 경우 더 정확한 얼굴인식률을 달성할 수 있다.


【특허청구범위】

【청구항 1】

얼굴 요소별로 추출된 LDA 프로젝션을 하나의 단일 벡터로 머징하고 GDA를 사용하여 최종 얼굴 디스크립션을 산출하는 것을 특징으로 하는 LDA 프로젝션에 GDA를 적용한 얼굴 디스크립션 산출 방법.

【도면】

【도 1】



(Translation)

KOREAN INTELLECTUAL PROPERTY OFFICE

This is to certify that the following application annexed hereto is a true copy from the records of the Korean Intellectual Property Office.

Application Number: 10-2002-0087920

Date of Application: December 31, 2002

Applicant(s): Samsung Electronics Co., Ltd.

Dated this 10th day of July, 2003

Commissioner (Seal)